07｜回归分析：怎样用模型预测用户的生命周期价值？

2021-09-13 黄佳

《零基础实战机器学习》 课程介绍 >

讲述：黄佳
时长 22:38 大小 20.74M

你好，我是黄佳。

首先，恭喜你成功通过“获客关”。在获客关中，我们把互联网电商“易速鲜花”的用户们分成了高、中、低三个价值组，你还记得这个项目是属于监督学习还是无监督学习吗？没错，是无监督学习。

今天，我们开启“变现关”的挑战。而且我们将进入更为常见、更主流的机器学习应用场景，监督学习的实战。更确切地说，这是用监督学习解决回归问题的一次实战。监督学习，主要应用于回归和分类两大场景，分别可以用来预测数值和进行分类判断，这两类问题也是我们课程的两大重点。在这节课中，你就能够学到用回归来进行数值预测的方法了。因为这是监督学习项目，所以，我们会完全跟着前面讲的“机器学习实战 5 步”来走。

定义问题

请你想象一下，你刚为客户做了分组画像，老板推门而入：“价值分组这个项目做得不错嘛！现在有这么一个新需求，你看看你这边还有什么 idea。”

他继续说道：“你也知道，现在流量太贵了，拉新成本平均下来每注册一个用户我几乎要花接近 500 元。我是这么想的。500 元，说贵也贵，说不贵也不贵，关键还是要看这些用户能给我们带来多大价值、多大回报，你说对吧？要是多数人用我们的 App，用几次就不用了，订花的总消费甚至比 500 元还少，那就没什么意思了。所以，你看能不能根据历史数据，预测一下新用户未来一两年的消费总额？”

好，那现在我们来分析一下这个问题。其实，这个问题的实质是计算一个用户使用某产品的过程中消费总量是多少。比如某类手机 App，用户的平均使用长度是两年左右，那么两年内用户在 App 上消费所产生的总收益就是用户的生命周期价值，英文是 Lifetime Value，简称 LTV，有时我们也叫 CLV（Customer Lifetime Value）。

请你想想看，如果你得到一个新用户的成本是 500 元，看上去是很贵，但如果这个人在你的店铺买花的钱预计会超过万元，那么扣除进货成本和获客成本，你还是赚到了，ROI 高嘛。

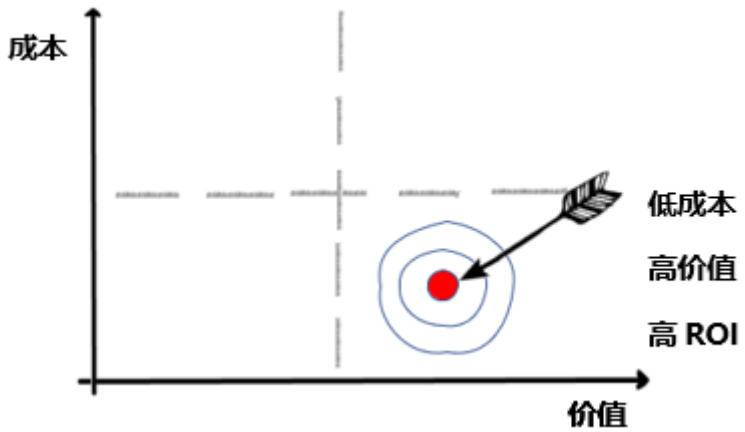

用户的LTV越高，我们ROI越高

所以，我们的目标就是通过现有数据，找到一个能预测出用户生命周期价值的模型，来指导我们获客的成本，避免超出回报的盲目投入。

那对于这个问题，我们还是会使用上一个项目中的原始数据集，你在这里就能下载到。拿到数据集后，我们就可以开始数据的预处理工作了。

数据预处理

通过前面的课程，我想你应该已经想到：“用户生命周期价值”是一种连续性数值，对这种连续性数值的预测，属于一个回归问题。那么，在数据预处理阶段，我们就要确定把哪些特征字段输入到回归模型中。

	A	B	C	D	E	F	G	H
1	订单号	产品码	消费日期	产品说明	数量	单价	用户码	城市
2	536374	21258	6/1/2020 9:09	五彩玫瑰五支装	32	10.95	15100	北京
3	536376	22114	6/1/2020 9:32	茉莉花白色25枝	48	3.45	15291	上海
4	536376	21733	6/1/2020 9:32	教师节向日葵3枝尤加利5枝	64	2.55	15291	上海
5	536378	22386	6/1/2020 9:37	百合粉色10花苞	10	1.95	14688	北京
6	536378	85099C	6/1/2020 9:37	橙黄香槟色康乃馨	10	1.95	14688	北京
7	536378	21033	6/1/2020 9:37	满天星干花花束	10	2.95	14688	北京

我们看到，这个数据集的字段包括订单号、产品码、消费日期、产品说明、数量（订单）、单价、用户码和城市。那么，哪些字段和用户的 LTV 相关呢？

很显然，像订单号、用户码、产品说明这些信息，肯定和用户的 LTV 值是不相关的。你可能会说，用户所在的“城市”这个字段，也许和用户的消费能力有一定的关联。

这看起来有一定的道理。不过，像“北京”、“上海”这样的文本字段肯定不能直接被输入回归模型，如果要考虑城市信息，也应该转换为 0、1 的哑变量值，再输入模型。也就是说转换成“是否北京”(值是 0 或 1)，“是否上海”（值是 0 或 1），“是否深圳”（值是 0 或 1）.....

你看，这样一下子就增加了好多个特征，而且对这个数据集来说，城市对于 LTV 值的影响其实并不大。综合这些因素，在这个项目中，我们就不考虑“城市”这个字段了。

看到这，你也许会想：那这么说的话，用户的消费金额肯定和 LTV 非常相关，可是，用户的消费金额不就是 LTV 本身嘛，用自己去预测自己，这样的模型有什么意义呢？

这个想法没错，用户的消费金额确实是和 LTV 最为相关的变量。不过，我们要做两个小调整，来解答你的困惑。

第一个调整是，我们可以考虑用头 3 个月的消费金额，而不是全部一整年的消费金额，来预测用户后续一年或两年的“价值”。这样，根据历史数据搭建起模型后，对于新注册的

用户，我们只需要观察其头 3 个月的表现，就能够预测他今后一、两年的消费总量。如果某类 App 用户平均使用长度是一年或两年的话，这也就是该用户的生命周期价值。

第二个调整是，用我们在前两节课中学到的 R、F、M 值来做特征变量，这就避免了单一维度建模的局限性。在 RMF 用户分组中，我们不仅可以得到消费金额，还能得到新近度、消费频率。这些层级把消费频率、最近消费日期这些非数值变量转化成了数值变量，而且这些数值与用户的 LTV 也都密切相关。

因此，**在我们的模型中，可以用头 3 个月的 R、F、M 这 3 个数值作为特征，也就是回归模型的自变量。而回归模型所要预测的因变量，即数据集的标签，就是一年的总消费额，你可以认为它就是用户的 LTV。**

我要说明一下，这里的 3 个月、12 个月都只是思路上的示意，我们不去考虑用户平均会使用该 App 一年还是两年、三年。在不同业务场景中，计算 RFM 特征值的时间区间和 LTV 的时间区间可以视情况而定。

下面我们要做的就是数据清洗，这其中包括删除不符合逻辑的负值、查看有没有缺失值、添加每个订单的总价字段等。这部分内容和上一讲的类似，我就不再重复了，你如果不清楚，可以去回顾上一讲的内容。

在数据预处理阶段，唯一不同的就是，当前项目需要显示数据集的时间跨度，因为我们要拆分出头 3 个月的数据作为输入特征，并且只考虑 12 月的总消费金额作为 LTV，所以我们要通过数据集的时间跨度来把它分为两部分，一部分用来构建 RFM 特征（头 3 个月），另一部分用来构建 LTV 这个标签（整个 12 个月）。

1. 整理数据集记录的时间范围

通过这段代码，我可以知道当前数据集一共覆盖了多长的时间。

复制代码

```
import numpy as np #导入NumPy
import pandas as pd #导入Pandas
df_sales = pd.read_csv('易速鲜花订单记录.csv') #载入数据
print('日期范围: %s ~ %s' % (df_sales['消费日期'].min(), df_sales['消费日期'].max(
df_sales['消费日期'] = pd.to_datetime(df_sales['消费日期']) #转换日期格式
print('日期范围: %s ~ %s' % (df_sales['消费日期'].min(), df_sales['消费日期'].max(
```

输出如下：

```
日期范围（格式转化前）： 1/1/2021 10:11 ~ 9/9/2020 9:20
日期范围（格式转化后）： 2020-06-01 09:09:00 ~ 2021-06-09 12:31:00
```

结果显示，数据集中的时间跨度是从 2020 年 6 月到 2021 年 6 月 9 号。

因为我们希望求的是整年的 LTV，所以，这里我们把不完整的 2021 年 6 月份的数据删除：

```
df_sales = df_sales.loc[df_sales['消费日期'] < '2021-06-01'] #只保留整月数据
print('日期范围: %s ~ %s' % (df_sales['消费日期'].min(), df_sales['消费日期'].max(
```

输出如下：

```
日期范围（删除不完整的月份）： 2020-06-01 09:09:00 ~ 2021-05-31 17:39:00
```

目前的数据集中，共包含了整整 12 个月的数据。下面，我们开始构建机器学习数据集的特征和标签字段。

2. **构建特征和标签**

基于前面的分析，我们用前 3 个月的 R、F、M 值作为特征字段，然后把整个 12 个月的消费金额视为 LTV，作为标签字段。

首先，我们把头 3 个月的销售数据拆分出来，形成独立的 df_sales_3m 对象。这部分数据将是对用户 LTV 预测的依据。

```
df_sales_3m = df_sales[(df_sales.消费日期 > '2020-06-01') & (df_sales.消费日期 <=
```

```
df_sales_3m.reset_index(drop=True) #重置索引
```

接下来，我们创建以用户码为主键的 df_user_LTV 对象，利用头 3 个月的数据，构建 R、F、M 层级，形成新特征。具体的思路和步骤，我们在第 5 讲中讲解过，我就不啰嗦了：

复制代码

```
df_user_LTV = pd.DataFrame(df_sales['用户码'].unique()) #生成以用户码为主键的结构
df_user_LTV.columns = ['用户码'] #设定字段名
df_user_LTV.head() #显示头几行数据
df_R_value = df_sales_3m.groupby('用户码').消费日期.max().reset_index() #找到每个
df_R_value.columns = ['用户码','最近购买日期'] #设定字段名
df_R_value['R值'] = (df_R_value['最近购买日期'].max() - df_R_value['最近购买日期']
df_user_LTV = pd.merge(df_user_LTV, df_R_value[['用户码','R值']], on='用户码') #
df_F_value = df_sales_3m.groupby('用户码').消费日期.count().reset_index() #计算每
df_F_value.columns = ['用户码','F值'] #设定字段名
df_user_LTV = pd.merge(df_user_LTV, df_F_value[['用户码','F值']], on='用户码') #
df_M_value = df_sales_3m.groupby('用户码').总价.sum().reset_index() #计算每个用户
df_M_value.columns = ['用户码','M值'] #设定字段名
df_user_LTV = pd.merge(df_user_LTV, df_M_value, on='用户码') #把消费总额整合至df_u
df_user_LTV #显示用户表结构
```

最后，我们输出显示 df_user_LTV 对象，就会看到头三个月的 R 值、F 值、M 值都已经作为特征，存到我们的数据集 df_user_LTV 中了。到这里，特征构建完毕。

	用户码	R值	F值	M值
0	15100	49	3	876.00
1	15291	41	33	1372.19
2	14688	6	82	1491.37
3	15311	5	696	12877.85
4	15862	89	64	354.23

下面我们再来看怎么构建数据集的标签。

我们说过，标签，就是我们需要去预测或者判断的东西。而机器学习，就是通过已知来预测未知，通过训练数据集来寻找规律，发现特征和标签之间的联系。所以，我们下一步要做的，就是把 LTV 值加入到 df_user_LTV 中，这样数据集才完整。

我们先根据一整年的数据计算出每一个用户的 LTV 值，也就是 12 个月的总消费金额：

复制代码

```
df_user_1y = df_sales.groupby('用户码')['总价'].sum().reset_index() #计算每个用户
df_user_1y.columns = ['用户码','年度LTV'] #设定字段名
df_user_1y.head() #显示头几行数据
df_LTV = pd.merge(df_user_LTV, df_user_1y, on='用户码', how='left') #构建整体LTV
df_LTV #显示df_LTV
```

然后，再把得到的 LTV 值整合到之前构建的 df_user_LTV 中，就形成了完整的、带标签的 LTV 数据集。

	用户码	R值	F值	M值	年度LTV
0	15100	49	3	876.00	876.00
1	15291	41	33	1372.19	4668.30
2	14688	6	82	1491.37	4971.00
3	15311	5	696	12877.85	59591.83
4	15862	89	64	354.23	659.73
...	...	...	...	...	...
356	15951	1	22	375.17	375.17
357	14745	1	7	240.60	1220.26
358	15724	0	5	103.65	218.25
359	15874	0	5	584.35	4405.88
360	15656	0	15	242.95	748.50

361 rows × 5 columns

现在，在这个数据集中，R、F、M 值来自于头 3 个月收集的数据，是模型的特征；LTV 值来自于整年的数据，是模型的标签。这非常符合我们的目标：**用短期数据，来预测用户的长期价值**。

数据集形成之后，你会发现用户的数量从原来的 981 个减少到了 361 个，这是因为在头三个月出现过消费行为的用户数就只有 361 个。所以，我们后续基于这 361 个用户的数据来开展机器学习建模就可以了。

3. 创建特征集和标签集

刚刚我们把特征和标签整合在一起，是为了形成完整的数据集。不过，标签集和特征集要分别输入机器学习模型，所以要分别创建。

我们先来构建特征集 X：

```
X = df_LTV.drop(['用户码','年度LTV'],axis=1) #特征集
X.head() #显示特征集
```

在这段代码中，我们除了移除了 LTV 值之外，还移除了用户码字段。因为用户码对于回归模型的训练毫无意义，而且用户码也是数字，会对模型形成干扰。如果不移除的话，机器就会把它也视作一个变量，认为 15291 比 15100 大，这显然不合逻辑。

然后，我们再来构建标签集 y。这里多说一句，在机器学习中，特征集的 X 大写，标签集的 y 小写，似乎是个惯例。这可能是因为通常情况下，X 是一个向量，而 y 是一个数值。

```
y = df_LTV['年度LTV'] #标签集
y.head() #显示标签集
```

构建好特征集和标签集后，我们就可以把它们拆分为训练集、验证集和测试集了。

4. **拆分训练集、验证集和测试集**

我们用 scikit-learn 工具包中的拆分工具 train_test_split，进行拆分：

```
from sklearn.model_selection import train_test_split
# 先拆分训练集和其它集
X_train, X_rem, y_train, y_rem = train_test_split(X,y, train_size=0.7,random_s
# 再把其它集拆分成验证集和测试集
X_valid, X_test, y_valid, y_test = train_test_split(X_rem,y_rem, test_size=0.5
```

请你注意，这里我做了两重的拆分，至于为什么要这样做，你可以回顾下第三讲的内容。

最后，我们得到的数据集 X_train、X_valid 和 X_test 的字段，与 X 中的字段还是一样，y_train、y_valid、y_test 中的字段和 y 的也一样，只是它们的行数发生了改变：

X_train 是 288 行×4 列；

y_train 是 288 行×1 列；

X_valid 是 73 行×4 列；

y_valid 是 73 行×1 列；

X_test 是 73 行×4 列；

y_test 是 73 行×1 列。

好，到这里，我们的数据准备工作就全部完成啦。在这个项目中，这部分工作几乎占了大头，好在我们已经攻克，下面我们一起进入选算法并创建模型的环节。

选择算法创建模型

因为这是一个回归问题，所以，在模型类型的选择方面，我们肯定使用的是回归算法。这是基于问题本身的性质而确定的，毋庸置疑。

不过我们说过，在机器学习中，能够解决回归问题的常见算法有不少：

常见回归算法	说明
线性回归	利用线性回归方程的最小二乘函数，对一个或多个自变量和因变量之间的关系，进行建模的一种回归分析。
贝叶斯回归	使用统计学中贝叶斯推断（Bayesian inference）方法求解的线性回归（linear regression）模型。
SVM回归（SVR）	通过SVM解决回归问题，就是找到一个回归平面，让一个集合的所有数据到该平面的距离最近。
决策树	主要指CART(classification and regression tree)算法，内部结点特征的取值为“是”和“否”， 为二叉树结构。用决策树解决回归问题，就是根据特征向量来决定对应的输出值。
随机森林	用多棵决策树组合而成的一种集成学习模型。
AdaBoost和XGBoost等梯度提升算法	利用Boosting方法基于树模型建立的集成学习模型。
神经网络算法	由一组相互连接的神经元构建出来的深度学习模型。

极客时间

一般来说，我们在解决具体问题的时候，会选择多种算法进行建模，相互比较之后，再确定比较适合的模型。由于篇幅所限，我们不会使用上述全部算法建立模型，这里我会带你比较 3 种算法的效率：最基本的线性回归模型、决策树模型和随机森林模型（你可以自己试着使用其它的算法创建别的模型）。

线性回归我们已经用过了，它是通过梯度下降找到最优的权重和模型偏置的最基本的回归算法。这里，我会用它做为一个基准模型，把其它模型的结果与其相比较，来确定优劣。

而决策树算法，简单地说是从样本数据的特征属性中，通过学习简单的决策规则，也就是我们耳熟能详的 IF ELSE 规则，来预测目标变量的值。这个算法的核心是划分点的选择和输出值的确定。

下面，我给你画了一张图，来帮你理解决策树是怎么进行判断预测的。

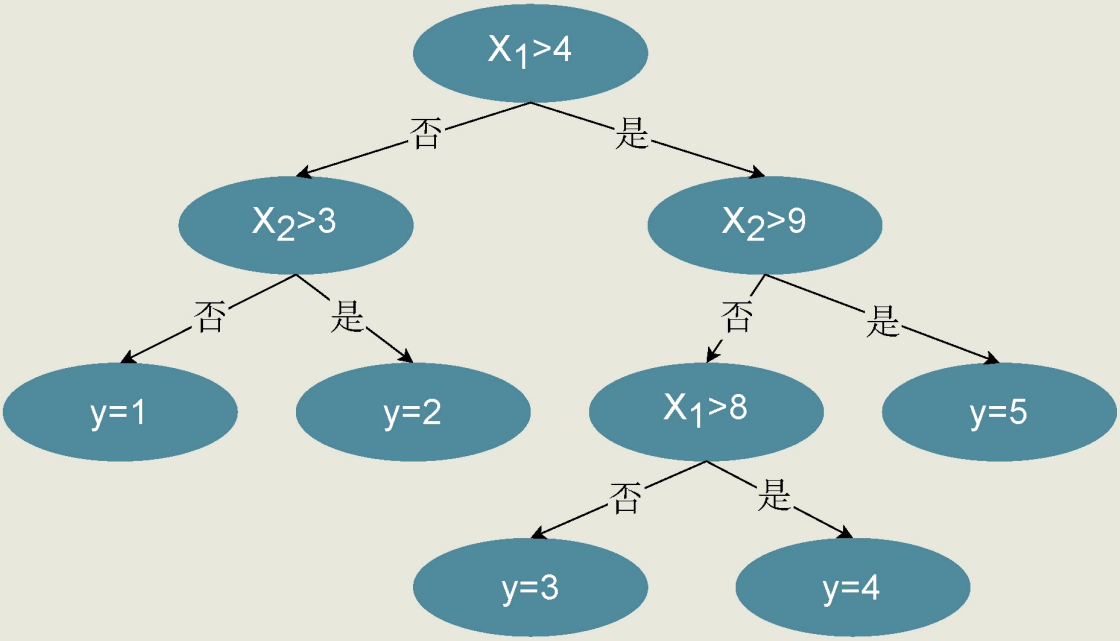

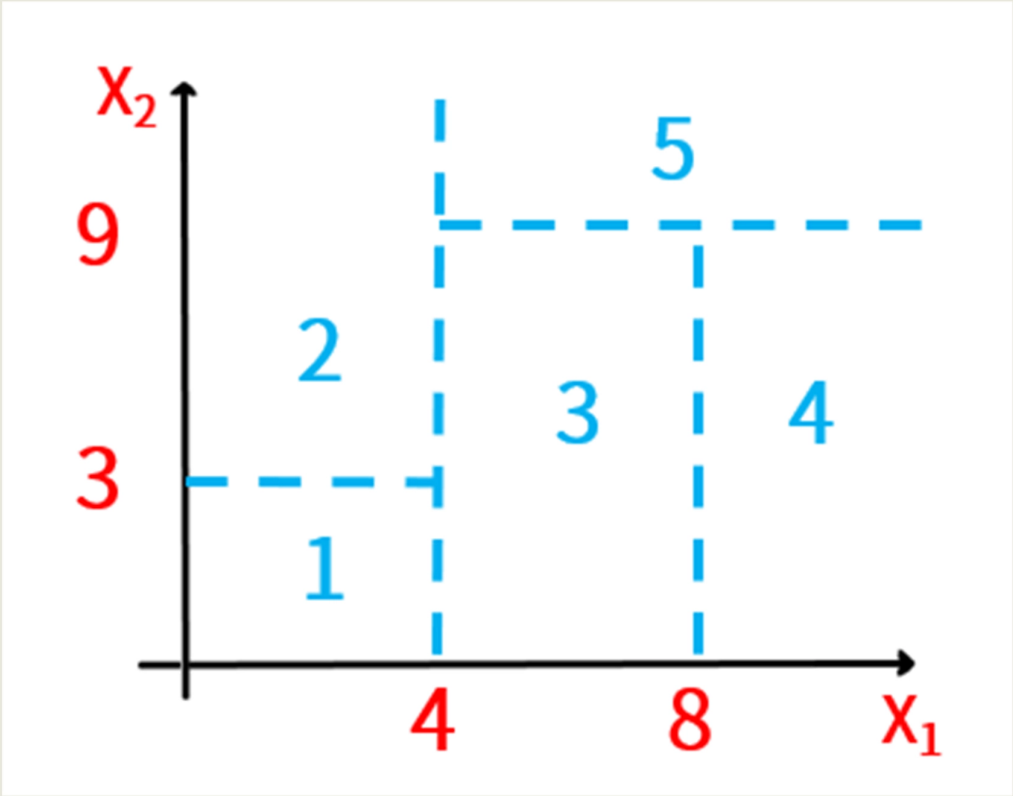

极客时间

你可以看到，这种算法是根据两个特征 x_1 和 x_2 的值，以及标签 y 的取值，来对二维平面上的区域进行精准分割，以确定从特征到标签的映射规则。根据树的深度和分叉时所选择的特征的不同，我们可以训练出很多棵不一样的树来。

而随机森林呢，就是由多棵决策树构成的集成学习算法。它既能用于分类问题，也能用于回归问题。而且无论是解决哪类问题，它都是相对优秀的算法。在训练模型的过程中，随机森林会构建多个决策树，如果解决的是分类问题，那么它的输出类别是由个别树输出的类别的众数而定；如果解决的是回归问题，那么它会对多棵树的预测结果进行平均。

关于集成学习，我后面还会单独拿出来给你讲解。现在你只需要知道，随机森林纠正了决策树过度拟合其训练集的问题，在很多情况下它都能有不错的表现。这里的“过拟合”，其实就是说模型对训练集的模拟过头了，反而不太适合验证集和测试集。

下面我们导入并创建线性回归模型、决策树模型和随机森林模型。

复制代码

```
from sklearn.linear_model import LinearRegression #导入线性回归模型
from sklearn.tree import DecisionTreeRegressor #导入决策树回归模型
from sklearn.ensemble import RandomForestRegressor #导入随机森林回归模型
model_lr = LinearRegression() #创建线性回归模型
model_dtr = DecisionTreeRegressor() #创建决策树回归模型
model_rfr = RandomForestRegressor() #创建随机森林回归模型
```

在代码中，有几个缩写我解释一下：

lr 是 Linear Regression（线性回归）的缩写；

dtr 是 Decision Tree Regresssor（决策树回归）的缩写；

rfr 是 Random Forest Regressor（随机森林回归）的缩写。

对于决策树和随机森林算法来说，它们既有回归算法（Regressor），也有分类算法（Classifer）。以后，我们用到分类模型的时候，我就会把决策树分类模型命名为 model_dtc，把随机森林分类模型命名为 model_rfc，其中的“c”就代表 Classifer。

创建好模型之后，我们就可以开始训练机器了。

训练模型

我们直接对线性回归、决策树模型和随机森林模型进行训练、拟合：

```
model_lr.fit(X_train, y_train) #拟合线性回归模型
model_dtr.fit(X_train, y_train) #拟合决策树模型
model_rfr.fit(X_train, y_train) #拟合随机森林模型
```

复制代码

你不要小看上面这几个简单的 **fit 语句，这是模型进行自我学习的关键过程**。我们前面说了，在线性回归算法中，机器是通过梯度下降，逐步减少数据集拟合过程中的损失，让线性函数对特征到标签的模拟越来越贴切。而在决策树模型中，算法是通过根据特征值选择划分点来确定输出值的；在随机森林算法中，机器则是生成多棵决策树，并通过 Bagging 的方法得到最终的预测模型。

不过，拟合之后的模型是否有效，我们还无法确定，需要进行验证集上的预测并验证预测结果。

评估模型

下面我们用这三种模型对验证集分别进行预测。

```
y_valid_preds_lr = model_lr.predict(X_valid) #用线性回归模型预测验证集
y_valid_preds_dtr = model_dtr.predict(X_valid) #用决策树模型预测验证集
y_valid_preds_rfr = model_rfr.predict(X_valid) #用随机森林模型预测验证集
```

复制代码

为了看看这些模型预测的 LTV 值是否大体上靠谱，我们先来随机选择其中一行数据，看看模型的预测结果。

```
X_valid.iloc[2] #随便选择一个数据
```

复制代码

这行数据的特征如下：

```
R值       1.00
F值     153.00
M值    1413.83
Name: 163, dtype: float64
```

复制代码

然后，我们再显示一下三个模型对这一行数据所预测的 LTV 值，以及该用户的 LTV 真值。

复制代码

```
print('真值:', y_valid.iloc[2])  #真值
print('线性回归预测值:', y_valid_preds_lr[2])  #线性回归模型预测值
print('决策树预测值:', y_valid_preds_dtr[2])  #决策树模型预测值
print('随机森林预测值:', y_valid_preds_rfr[2]) #随机森林模型预测值
```

输出：

复制代码

```
真值: 4391.9399999999905
线性回归预测值: 7549.22894678151
决策树预测值: 4243.209999999997
随机森林预测值: 4704.671799999999
```

可以看到，相对而言，对这个数据点来说，决策树和随机森林所预测的 y 值更接近真值。

当然，一个数据点接近真值完全不能说明问题，我们还是要用 R^2、MSE 等评估指标在验证集上做整体的评估，比较模型的优劣。

下面我们用 R^2 指标，来评估模型的预测准确率：

复制代码

```
from sklearn.metrics import r2_score,   median_absolute_error #导入Sklearn评估模
print('验证集上的R平方分数-线性回归: %0.4f' % r2_score(y_valid, model_lr.predict(X_
print('验证集上的R平方分数-决策树: %0.4f' % r2_score(y_valid, model_dtr.predict(X_
print('验证集上的R平方分数-随机森林: %0.4f' % r2_score(y_valid, model_rfr.predict(
```

输出如下：

复制代码

```
验证集上的R平方分数-线性回归: 0.4333
验证集上的R平方分数-决策树: 0.3093
验证集上的R平方分数-随机森林: 0.4677
```

我们把这个结果用图表来显示一下，会更加直观：

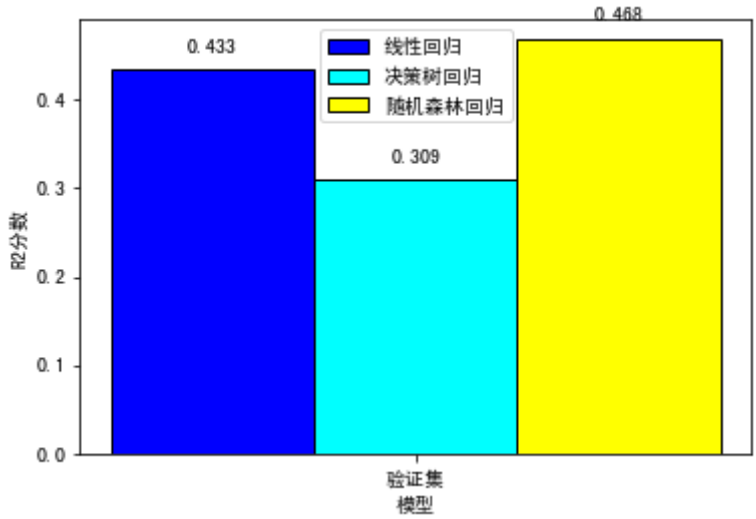

我们可以看到，在都没有经过任何参数设定的情况下，和线性回归、决策树相比，随机森林算法显示出了更好的预测能力。

复制代码

```
最后，我们在随机森林上面运行测试集，并绘制出预测值和真值之间的散点图：
y_test_preds_rfr = model_lr.predict(X_test) #用模型预随机森林模型预测验证集
plt.scatter(y_test, y_test_preds) #预测值和实际值的散点图
plt.plot([0, max(y_test)], [0, max(y_test_preds)],   color='gray', lw=1, lines
plt.xlabel('实际值') #X轴
plt.ylabel('预测值') #Y轴
plt.title('实际值 vs. 预测值') #标题
```

输出如下：

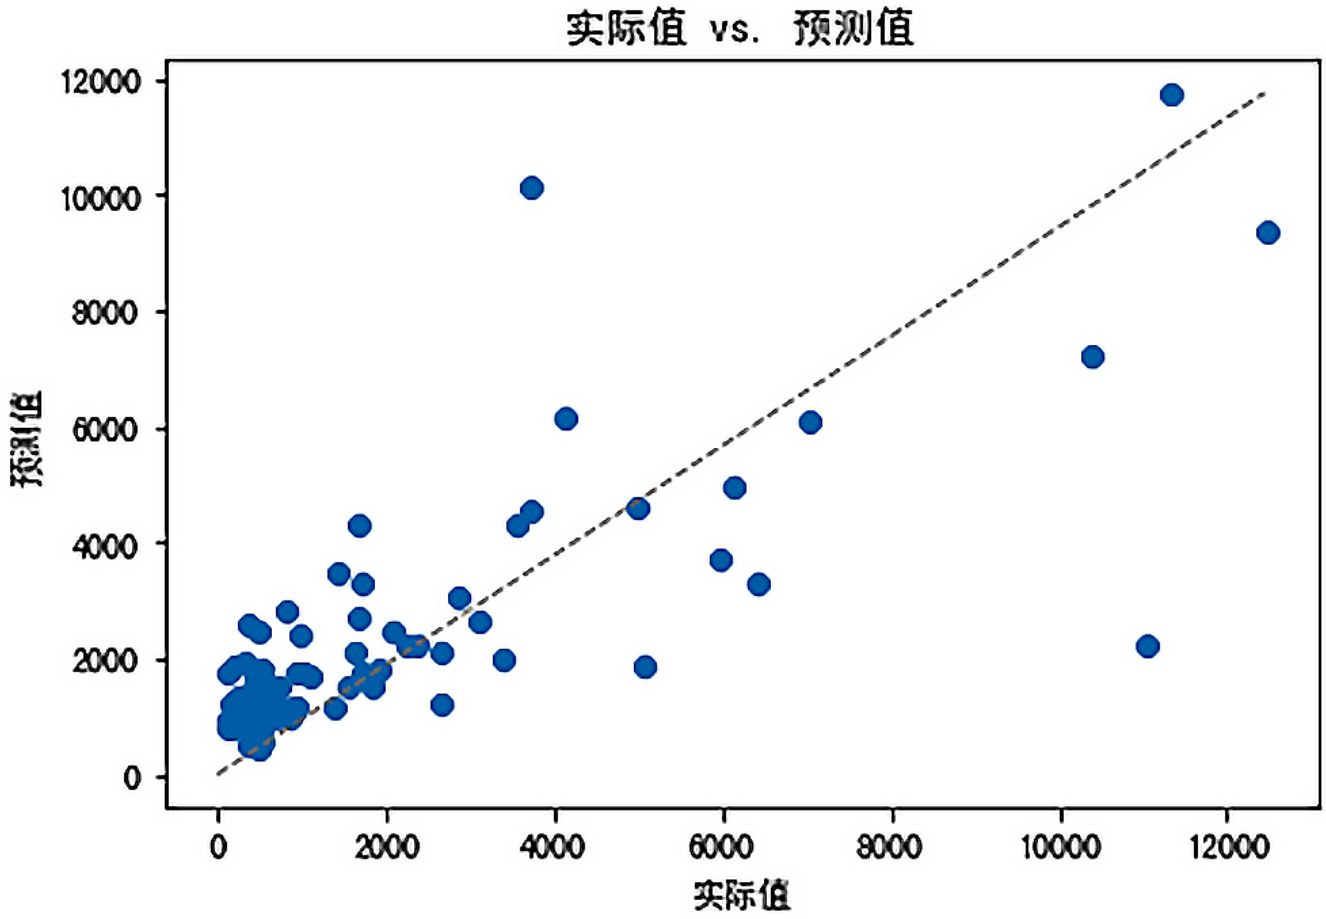

我们希望实际值和预测值基本上是相等的（预测值越接近真值，则误差越小）。举例来说，图中一个全年消费 12000 元的用户，所预测出来的 LTV 值，也在 12000 元左右。这样的情况越多，就表明模型越准确。

现在有了这个机器学习模型，我们再回过头看一下，在这一讲的开始，老板提出的问题：如何判断获客成本是否过高？根据模型预测结果，我们可以进一步观察处于 R、F、M 各个层级中的用户，看他们的 LTV 值大概是多少，这样就不难得知每个层级的获客成本应该控制在什么范围了。

对于高 RFM 价值的客户来说，我们可以适当多投入获客成本；而对于低 RFM 价值的客户，我们就要严格控制获客成本了。所以，根据这个模型，我们可以得出一个**获客成本的指导区间**。而且，通过该模型，我们**还可以便捷地计算出每个新用户的 LTV 值。**

总结一下

好，今天这一讲到这里就结束了，我们来回顾一下你在这节课中学到了什么。

在这一讲中，我们应用机器学习的实战 5 步，解决了一个回归问题。在这一过程中，最重要的部分是构建特征，也就是把原始数据，转化成 R 值、F 值和 M 值，来作为新特征进行机器学习。而**这个过程本身就是一个很有意思的特征工程**。

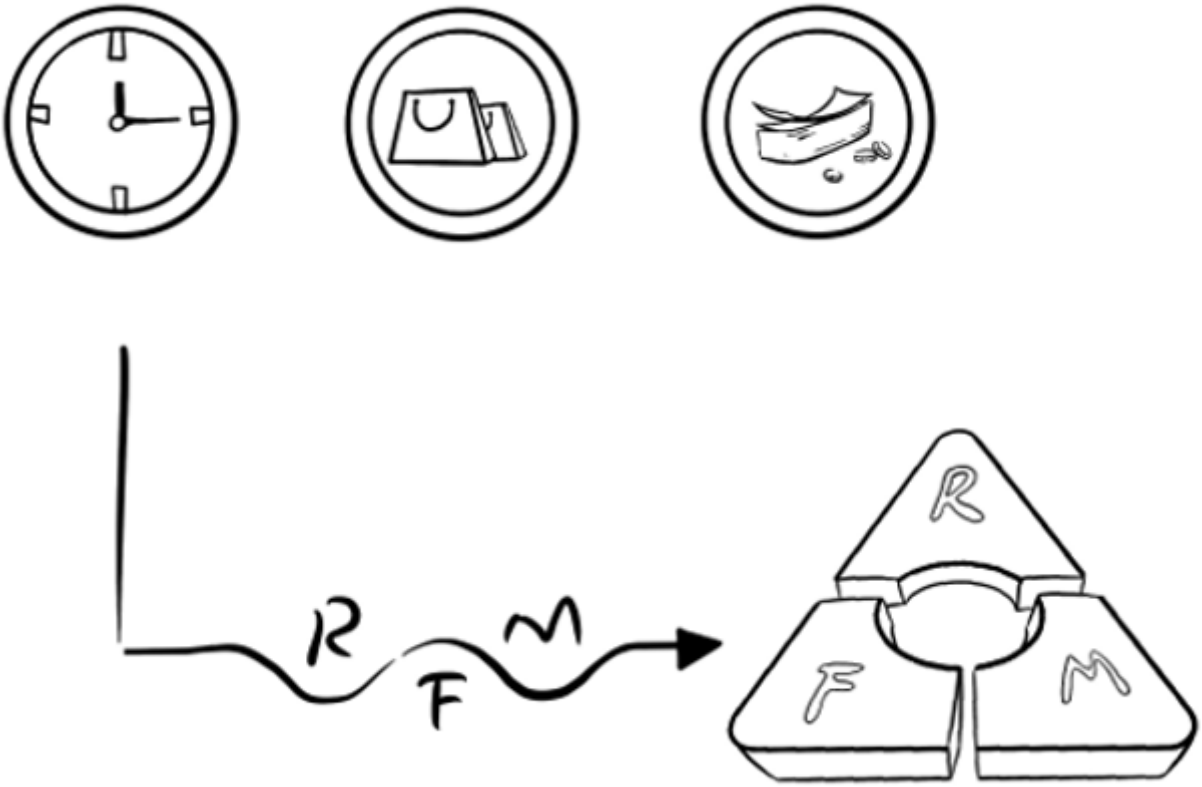

在模型选择的方面，我们使用普通的线性回归算法作为基准模型。然后，再拿其它的算法（这里我们选择的是决策树和随机森林）与之比较，从而找出更优的算法。请你注意，这里所谓的更优，仅针对于当前的场景而言，并不是说随机森林算法就一定优于线性回归算法。

当然，一般来说，随机森林简单且容易解释。如果对于任何一个特定问题，你能找到比随机森林还好的算法，那么就可以说是相当成功了。

在这次实战中，我们只是简单地调用模型，还并没有进行任何的参数优化步骤。以后，我们还会对随机森林算法做调优的工作。

思考题

这节课就到这里了，最后，我给你留 3 个思考题：

1. 在这次实战中，我们放弃了用户所在的“城市”这个信息，请你使用 Pandas 中的 get_dummies 这个工具，来添加“城市”相关的哑变量，然后添加到特征集中，输入模型。

提示：

复制代码

```
city = pd.get_dummies(df_sales.城市, prefix='城市')
df_sales = pd.concat([df_sales, city], axis=1)
```

2. 其实，SVM 和朴素贝叶斯也可以解决回归问题，请你使用这两种算法（或其它回归算法）来尝试解决这个问题，然后比较各个算法的优劣。

提示：

复制代码

```
from sklearn.svm import SVR
from sklearn.linear_model import BayesianRidge
```

3. 在验证时，我选择了 R^2 作为回归问题的评估指标，你能否尝试使用均方误差、中值绝对误差等评估指标，来验证我们的模型呢？

提示：除了 R^2 是越大越好之外，其它评估指标都是越小越好。

复制代码

```
from sklearn.metrics import mean_squared_error
from sklearn.metrics import median_absolute_error
```

欢迎你在留言区分享你的想法和收获，我在留言区等你。如果这节课帮到了你，也欢迎你把这节课分享给自己的朋友。我们下一讲再见！

极客时间

本讲重点

我们遵循监督学习实战 5 步完成了 LTV 的预测：

定义问题：预测用户 LTV 值；

数据预处理：此步骤的关键是构建出头三个月的 R、F、M 值为特征，全年的 LTV 值为标签；

选择算法：创建出线性回归、决策树和随机森林三个模型；

训练模型：用同样的数据集训练上面三个模型；

评估模型：对三个模型进行评估、比较，选出最优的模型用在测试集上做测试。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 4 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 06 | 聚类分析：如何用RFM给电商用户做价值分组画像？

下一篇 08 | 模型优化（上）：怎么用特征工程提高模型效率？

精选留言 (8)

写留言

For Uuuuu 置顶

2021-09-13

有交流群吗？

展开

作者回复: 又，欢迎加群，方式见课程介绍链接。
https://time.geekbang.org/column/intro/438

3

AIK 置顶
2021-09-13

真值: 14389.900000000007
线性回归预测值: 150.00460000000007
决策树预测值: 106.2
随机森林预测值: 150.00460000000007
验证集上的R平方分数-线性回归: 0.3002...
展开

作者回复: 关于这个数据点的预测值和真值。这里有几个方面的考量。第一，我们的数据量比较小，只有几百个用户的数据。要得到更健壮的模型，需要很大量的数据。第二，从数据的角度，这个数据点他的前三个月和后12个月消费行为变化比较大。这个用户应该是前面消费很少，后期消费突然增多。那么，从我们这个示例模型的建模方式来说，对这种类型的用户，预测的就会很不准确，可以从特征选择、建模的方法来考虑有没有新的 idea。

其实啊，要预测未来的数值，理论上虽可行，但一定要做好有巨大误差的准备。这和预测股价类似，理论上模型可能预测一个上升趋势，但是实际上可能因为特殊因素突然大幅下跌。

1

在路上 置顶
2021-09-13

佳哥好，加上SVM和朴素贝叶斯算法之后R^2值为：
```
验证集上的R平方分数-线性回归: 0.4333
验证集上的R平方分数-决策树: 0.3286
验证集上的R平方分数-随机森林: 0.5130...
```
展开

作者回复: "写Demo的时候发现sklearn库非常强大，测试不同算法的效果非常容易。" ---- 太棒了，你发现了这一点，这个课程就没有白学了。用好它！😎

李冀 置顶
2021-09-13

“通过不同RFM层级就可以确定不同的获客成本”。但花钱引流时不知道RFM值啊，再建立一个渠道、城市到RFM的模型？感觉初期RFM到LTV的关系对促活更有指导意义，而不是拉新

作者回复: 对的。总结的好。RFM主要用于观察老用户，然后促进在老用户身上的营收增长，精细化运营。

在拉新过程中，也就是起到一些估计指导意义，大概估计一批新用户有可能带来的平均回报吧。

青松
2021-09-16

这个课程有jupyter notebook格式的文档吗？想一边教学一边实践

作者回复: 有啊，所有的jupyter notebook我不是都上载到GitHub里面了么。https://github.com/huangjia2019/geektime

Jove
2021-09-14

1、
df_C_value = (df_sales.groupby('用户码')[['城市_上海','城市_北京', '城市_广州', '城市_成都', '城市_深圳', '城市_苏州', '城市_西安']].sum() > 1)
df_LTV = pd.merge(df_LTV, df_C_value, on='用户码')
...
展开

作者回复: 好问题好问题。
评估标准不同，是有可能导致不同的结果的，你想一想：我们按照“采光情况”和“噪音大小”来评估房子，不会得到一样的分数，对不？这就是具体情况具体分析，你比较看重哪个指标。这就是不同的评估标准存在的意义。

那么，对于回归问题来说，简单来说R方更常用，算是一个基本公认的比较好的标准吧。

谦
2021-09-14

sklearn很好用，不过在实际项目中我经常需要把训练好的模型移植到其他平台上，例如用c语言重新实现一次预测模型，一般来说svm移植比较简单，找到coef_和intercept_，复

制一下就可以。决策树相对麻烦一点，要递归遍历整棵树，输出特征和阈值。随机森林或者使用决策树的adaboost就要遍历很多棵树。想请问佳哥在预测模型的移植和应用上有没有一些经验可以分享一下？谢谢😊

展开

作者回复: 在模型移植这方面，我的经验就相对有限一些。因为大的项目组中，负责建模和负责模型部署，或者模型移植复现的是两组人。让我来查阅一下相关方面的资料，然后在后面做一些分享。😁

李冀

2021-09-13

哪些模型适合用哪种度量值，这个有最佳实践吗

展开

作者回复: 无一定之规，机器学习建模时通常都会尝试多种可用的模型。